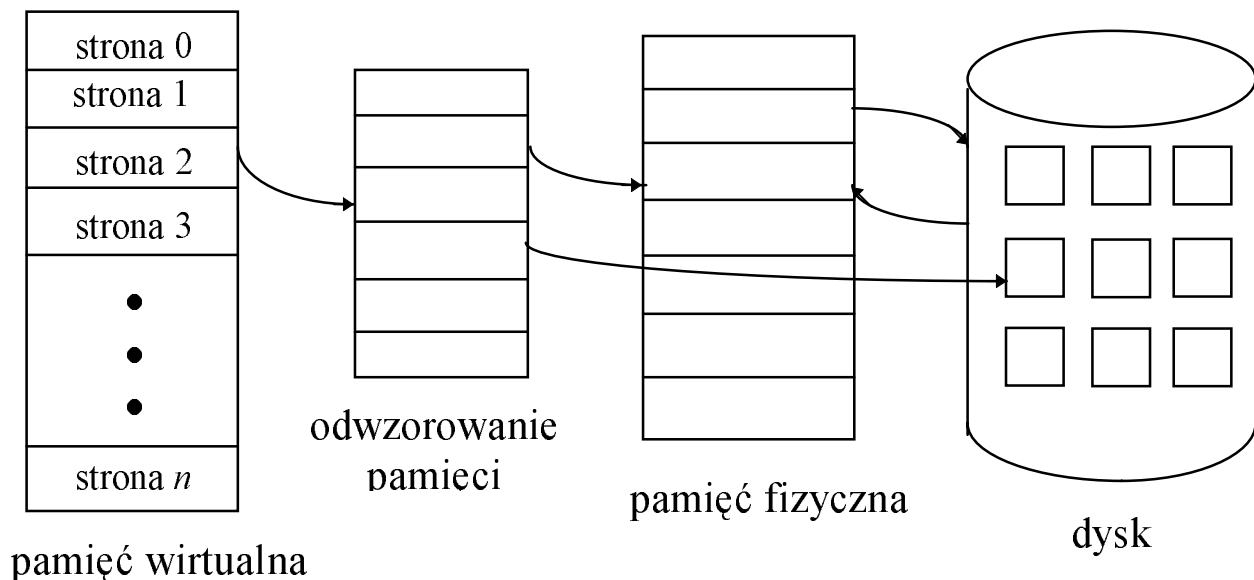


## Pamięć wirtualna

- Umożliwia wykonywanie procesów, pomimo że nie są one w całości przechowywane w pamięci operacyjnej
- Logiczna przestrzeń adresowa może być dużo większa od fizycznej przestrzeni adresowej
- Tworzy iluzję dużej, jednorodnej i szybkiej pamięci
- Techniki realizacji pamięci wirtualnej: stronicowanie na żądanie, segmentacja na żądanie, segmentacja ze stronicowaniem



### Stronicowanie na żądanie

- Strona jest sprowadzana do pamięci dopiero wtedy, gdy jest potrzebna:  
mniej wejścia-wyjścia, mniejsze zapotrzebowanie na pamięć, więcej użytkowników
- Strona jest potrzebna, gdy pojawia się do niej odwołanie
- Z każdą pozycją w tablicy stron jest związany *bit poprawności odwołania* (1 - strona w pamięci, 0 - strona poza pamięcią)

- Odwołanie do strony z bitem poprawności odwołania równym 0 powoduje **błąd braku strony** (ang. *page fault*).  
System operacyjny:
  - znajduje wolną ramkę
  - sprowadza stronę z dysku do pamięci
  - uaktualnia bit poprawności odwołania ( $:= 1$ )
  - restartuje instrukcję, która spowodowała błąd
- Co się dzieje, gdy nie ma wolnej ramki:  
**wymiana stron** (ang. *page replacement*) - SO znajduje w pamięci stronę (najmniej używaną) i usuwa ją na dysk
- Niektóre strony mogą być sprowadzane do pamięci wielokrotnie

### ***Wydajność stronicowania na żądanie:***

$p$  = współczynnik błędów braku strony  $0 \leq p \leq 1.0$

$p = 0 \Rightarrow$  nie ma błędów braku strony

$p = 1 \Rightarrow$  każde odwołanie powoduje błąd braku strony

*efektywny czas dostępu =*

$(1 - p) \times \text{czas dostępu do pamięci}$

$+ p \times \text{czas obsługi błędu braku strony}$

*obsługa błędu braku strony = czas obsługi przerwania*

$+ [\text{czas wysłania strony na dysk}] + \text{czas sprowadzenia}$

*strony z dysku + czas wznowienia obliczeń*

### ***Algorytmy wymiany stron:***

- *Bit modyfikacji* umożliwia zmniejszenie liczby transmisji dyskowych - tylko modyfikowane strony trzeba zapisywać z powrotem na dysk
- Algorytm powinien minimalizować liczbę błędów strony

- Ciąg odwołań: ciąg numerów stron, np.  
1, 2, 3, 4, 1, 2, 5, 1, 2, 3, 4, 5
  - **Algorytm FIFO**  
3 ramki pamięci  $\Rightarrow$  9 przerwania braku strony  
4 ramki pamięci  $\Rightarrow$  10 przerwania braku strony  
(*anomalía FIFO*; FIFO nie jest *algorytmem stosowym*)
  - **Algorytm optymalny**: usuń stronę, do której najdłużej nie będzie odwołania (alg. stosowy:  $M(m,r) \subseteq M(m+1,r)$ )  
3 ramki pamięci  $\Rightarrow$  7 przerwania braku strony  
4 ramki pamięci  $\Rightarrow$  6 przerwania braku strony  
Nierealizowalny w praktyce, stosowany do porównań
  - **Algorytm LRU** („najdłużej nieużywany najpierw”)  
3 ramki pamięci  $\Rightarrow$  10 przerwania braku strony  
4 ramki pamięci  $\Rightarrow$  8 przerwania braku strony  
*Implementacja z licznikiem*: z każdą pozycją w tablicy stron jest związany licznik, podczas każdego odwołania zawartość zegara kopiuje się do licznika  
*Implementacja ze stosem*: numery stron przechowuje się na stosie, po każdym odwołaniu do strony przesuwa się jej numer na wierzchołek stosu
- Algorytmy przybliżające LRU:**
1. *Bit odwołania*: z każdą stroną wiązuje się bit odwołania (inicjalnie = 0); w chwili odwołania do strony ustawia się bit na 1; usuwa się stronę z bitem 0; którą?
  2. *Algorytm drugiej szansy*: przegląda się strony zgodnie z porządkiem FIFO, cyklicznie; gdy bit=0, to stronę można wymienić; gdy bit=1; to zeruje się bit, a stronie daje „drugą szansę” (czas sprow. do pamięci:=czas bieżący)
  3. *Algorytm zegarowy*: jak w 2, lecz cykliczna lista stron
- **Algorytm LFU** („najmniej używana”)
  - **Algorytm MFU** („najwięcej używana”)

### ***Przydział ramek:***

- Minimalna liczba ramek zależy od architektury komputera
- *Przydział równy*: każdy proces dostaje tyle samo
- *Przydział proporcjonalny*: każdy proces dostaje proporcjonalnie do swojego rozmiaru
- *Przydział priorytetowy*: proces o wyższym priorytecie może wybrać stronę do usunięcia spośród swoich stron lub stron procesów o niższym priorytecie

**Algorytmy lokalne** (wybór strony do usunięcia spośród własnych stron) i **globalne** (wybór strony do usunięcia spośród wszystkich stron)

### **Migotanie**

Proces jest zajęty głównie przesyłaniem stron z dysku do pamięci i z pamięci na dysk

Brak wystarczającej liczby stron jest powodem wysokiego współczynnika błędów braku strony:

⇒ niskie wykorzystanie CPU

⇒ system operacyjny myśli, że trzeba zwiększyć poziom wieloprogramowości

⇒ do systemu dodaje się nowy proces

Wykres zależności wykorzystania procesora od poziomu wieloprogramowości

### **Model pola roboczego** (ang. *working-set*)

*Zasada lokalności odwołań*: w każdej fazie wykonania program korzysta jedynie z drobnej części całego zbioru stron (lokalność czasowa, przestrzenna)

T = parametr ⇒ *okienko* (ustalona liczba odwołań do stron)

*Pole robocze procesu*  $P_i$  ( $WS_i$ ): całkowita liczba stron, do których proces odwołał się podczas ostatnich  $T$  odwołań

Jeśli  $T$  za małe, to zbiór roboczy nie obejmie całej lokalności procesu

Jeśli  $T$  za duże, to zbiór roboczy obejmie kilka lokalności

Jeśli  $T = \infty$ , to zbiór roboczy obejmie wszystkie strony

### **Zasada pola roboczego a równoważenie obciążenia**

Jeśli są jeszcze wolne ramki  $\Rightarrow$  można zainicjować nowy proces

Jeśli  $\sum WS_i >$  liczba dostępnych ramek  $\Rightarrow$  migotanie  $\Rightarrow$  wstrzymanie jednego z procesów

### **Jak aproksymować zawartość pola roboczego:**

zegar + bit odniesienia

Przykład:  $T = 10,000$

- zegar generuje przerwanie co 5,000 jednostek czasu
- na każdą stronę przeznaczają się w pamięci dwa bity
- z nadejściem przerwania kopiuje się wszystkie bity odniesienia, a następnie zeruje
- jeśli jeden z bitów w pamięci = 1  $\Rightarrow$  strona należy do  $WS$

### **Inne zagadnienia:**

1. Sprowadzanie wstępne; OBL (ang. *one block lookahead*)
2. Wybór rozmiaru strony: fragmentacja, rozmiar tablicy stron, narzut na wejście-wyjście, lokalność
3. Struktura programu: przykład dostępu do macierzy kwadratowej wierszami vs. kolumnami  
*Restrukturyzacja programu: zwiększenie lokalności odwołań*


## 4. Blokowanie stron na czas operacji wejścia-wyjścia

### Segmentacja na żądanie

Używana w sytuacji, gdy brak sprzętu do implementacji stronicowania na żądanie

- *Problem umieszczania* jest poważniejszy od problemu wymiany
- OS/2 przydziela pamięć segmentami, które są opisane za pomocą *deskryptorów segmentów*
- Deskryptor segmentu zawiera *bit poprawności* wskazujący, czy segment znajduje się w pamięci (gdy nie, to pojawia się błąd braku segmentu)

### Hierarchie pamięci



b. szybka  
128 - 4K  
bajtów

b. szybka  
32K - 4M  
bajtów

szybka  
4M - 512M  
bajtów

wolna  
40M - 8G  
bajtów

### **Pamięć notatnikowa** (ang. *cache memory*)

- Czas dostępu: zbliżony do cyklu procesora
- *Współczynnik trafień* - miara efektywności pamięci notatnikowej (zwykle  $> 0.9$ , gdyż programy mają własność lokalności)
- Sposoby organizacji, sposoby zapisu, inicjowanie